

健康指向歩行ナビゲーションのための スマートフォンによる身体的負担度の推定

隅田 麻由¹ 今津 真也¹ 水本 旭洋¹ 安本 慶一¹

概要：

効果的かつ継続性の高いウォーキングのためには、個人の身体能力に応じた歩行ルートを選択が必須である。歩行中の身体的負担度は心拍数から推定可能であるが、心拍計などの特殊デバイスの装着は手間がかかる。本研究では、消費カロリーや歩行時間の制約を満たし、かつ、ユーザにとって負担度が最小となる歩行ルートを推薦するナビゲーションシステムの実現を目指し、スマートフォンで利用可能な機能のみを用いた身体的負担度の推定法を提案する。提案手法では、個々人の負担度および負担度の変化を推定するために、機械学習を基に、加速度や歩行速度などの歩行データから心拍数を予測する負担度モデルを作成する。実際のウォーキングで計測したデータに本手法を適用した結果、提案手法により平均絶対誤差 9.55bpm で心拍数の推定ができた。

Estimation of Perceived Exertion using Smartphone for Health-Conscious Walking Navigation

MAYU SUMIDA¹ SHINYA IMAZU¹ TERUHIRO MIZUMOTO¹ KEIICHI YASUMOTO¹

Abstract: For effective and continuous walking, it is necessary to select a walking route suitable for individual physical ability. Though perceived exertion during walking can be estimated by heart rate, it is costly for a user to equip with a special device such as a heart rate monitor. In this paper, aiming to realize a health-conscious walking navigation system that recommends a walking route with minimal perceived exertion satisfying constraints of calorie consumption and walking hours, we propose a method to estimate perceived exertion during walking with only available functions of a smartphone. For this purpose, we build a perceived exertion model which predicts the heart rate from walking data including acceleration and walking speed based on machine learning. We applied the proposed method to actual walking data and confirmed that the method estimates the heart rate within 9.55bpm.

1. はじめに

近年、運動不足に起因する生活習慣病の対策として、誰でも気軽に行うことができるウォーキングが注目されている。しかし、自分の体力にあったルートを選択しなければ、心臓や関節に負担がかかり、ウォーキングの意欲の低下につながる。特に高齢者や特定の持病保持者については、負

担が高い状態が続くことが危険な場合もある。

関連研究として、心拍計および加速度センサによる運動強度推定 [1][2] や心拍数予測 [3] を行う手法は存在するが、負担度の推定を目的としたものは存在しない。また既存ナビゲーションシステムでは、個人の身体能力を考慮したルートを検索することはできない。

本研究では、消費カロリーや歩行時間の制約を満たし、かつ、ユーザにとって負担度が最小となる歩行ルートを推薦するナビゲーションシステムの実現を目指し、様々な歩

¹ 奈良先端科学技術大学院大学
Nara Institute Science and Technology

行ルートに対する負担度推定手法を提案する。負担度の推定には、次に示す3つの課題が挙げられる。負担度は心拍数より測定可能であるが、心拍計の装着に手間がかかり(課題1)、個人差がある(課題2)。また、様々な歩行ルートに対する負担度の推定には大量のデータが必要であり、収集が困難である(課題3)。そこで、課題1および課題2の解決のため、年齢や性別などの属性により作成したカテゴリごとに、負担度モデルを作成する。負担度モデルとしては、スマートフォンから取得する加速度の振幅や周波数、歩行速度や道の勾配などのデータと、心拍計により計測した実際の心拍数データに機械学習を適用することで、心拍数予測モデルを構築する。加えて、課題3の解決のため、ユーザ参加型センシングによりデータを収集および共有し、歩行ルート検索時に負担度を推定できるようにする。

提案手法の評価では、負担度モデルに与える入力項目の検討および推定精度の評価を行う。ここでは、トレッドミルを用いて測定したデータにより、加速度の振幅や周波数など、11種類の特徴量から推定精度に影響を与える入力項目について検討する。そして推定精度の評価として、一般道で測定したデータから作成した負担度モデルを用意し、実測値とモデルより得られた予測値を比較することで、予測誤差および負担度の推定精度を算出する。評価実験の結果、トレッドミルによる実験では、入力として歩行速度および勾配から算出した酸素摂取増減値が有用であることが分かり、平均絶対誤差6.05bpmで心拍数を推定できた。また一般道における実験では、入力として加速度の振幅が有用であることが分かり、平均絶対誤差9.55bpmで心拍数を推定できた。

2. 関連研究

2.1節で述べるように、負担度は心拍数と強い関連性があり、また心拍数は運動強度によって変動することが分かっている。したがって本研究では、歩行中の運動強度と心拍数を関連付けることで、歩行中に感じる負担度を推定する。そのためには、歩行ルートに対する個々人の運動強度の推定および運動強度の変化の推定が必要である。

2.1 身体的負担度に関する知見

個人の身体的負担度の測定には、Borgが定義したRPE(主観的運動強度)[4]がよく用いられ、これは6から20までの15段階からなるボルグ・スケールとして知られている。RPEと心拍数との間には直線的な相関関係があり、スケールの数字は心拍数の1/10に対応している[5]。よって、これは主観的な運動強度を数値化する際に有効であり、心拍数と負担度の関連付けが可能となる。

2.2 運動強度推定に関する研究

Oscarら[1]、Tapiaら[2]は、加速度センサと心拍計を

併用し、「ウォーキング」や「ジョギング」などといった活動種別の推定[1][2]およびその運動強度の推定[2]を行っている。心拍数を特徴量とすることで推定精度が向上していることから、運動強度の推定には心拍数の利用が有用であると考えられる。

最近ではSUUNTO社のt6d[6]やPOLAR社のRS100[7]のような腕時計型のワイヤレス心拍計を用いることで、手軽に運動中の心拍数を測定できる。しかしこのような心拍計は、トランスミッターと呼ばれる装置を胸部に直接装着する必要があるため、装着に手間がかかり、煩わしい。加えて、デバイスコストが高いという問題もある。上記で挙げた既存研究は、複数の特殊デバイスの装着が必要であることから、手間やコストの問題が発生すると考えられる。

2.3 心拍数予測に関する研究

Fengら[3]は、ニューラルネットワークを用いた心拍数予測モデルを提案している。ここでは、3軸加速度センサにおける各軸の加速度および1ステップ前の心拍数予測値を入力として与えており、推定平均誤差5bpmで予測可能という結果が報告されている。これよりニューラルネットワークは運動強度と心拍数の関連付けの手段として利用できるが、Fengらは心拍数変動が少ない日常生活を対象としているため、ここで考案されているモデルは、本研究に必要な運動中の心拍数予測には使用できない。

2.4 既存のナビゲーションシステム

既存のナビゲーションシステムとして、ソニーの徒歩ナビゲーションNAV-U[8]や、NAVITIME社の自転車用ルート検索サービス[9]が挙げられる。これらのシステムでは、比較的負担の少ないルートを検索できるが、道の勾配を基準としており、個人の身体能力を考慮したルートを検索することはできない。そのため、坂道が少ないルートを選択した場合でも、人によっては負担を感じる事が考えられ、身体に無理な負担がかかる可能性がある。

2.5 本研究の位置付け

既存研究では、運動強度の推定や心拍数の予測が行われているが、運動中の負担度推定を目的とした研究は存在しない。更に2.2節で示したTapiaら[2]の研究では、数分間の運動を対象とした運動強度推定を行っているため、運動強度の変化は考慮されておらず、歩行ルートと運動強度の関連付けも行われていない。また、既存のナビゲーションシステムにおいても、個人の身体能力を考慮したルートを検索できるシステムは存在しない。

これより本研究では、スマートフォン搭載センサのみを用いた負担度推定手法を提案し、個々人の運動強度の推定および運動強度の変化の推定を行う。そしてこの手法に基づき、ユーザにとって負担が最小となる歩行ルートを推薦




図 1 システムの概要

するナビゲーションシステムを提案する。

3. 負担度を考慮したナビゲーションシステム

3.1 目的

本研究で提案する負担度を考慮したナビゲーションシステムは、無理なウォーキングによる継続性の低下、もしくは、怪我などの危険性を回避することを目的とする。そのため提案システムでは、歩行ルート検索時に、負担の少ない推薦歩行ルートとそのルートに対する負担度を提示する。またウォーキング中には、システムによって負担が高いと判断された場合にのみ警告を表示し、ユーザに歩行速度の調整を行ってもらふ。これにより、ユーザが推薦歩行ルート以外のルートを歩行する際にも、提案システムを利用することができる。

3.2 要件と基本方針

このシステムには、ユーザに提示する負担度の信頼性が必要となる。信頼性を向上させるためには、様々な歩行ルートに対する負担度や歩行データなどの大量なデータが必要であり、特殊デバイスを使用しない低コストかつ手軽なデータ収集法が求められる。更に、勾配のみを考慮した負担度ではなく、年齢や性別、運動習慣など個人の身体条件に適した負担度を提示することが望ましい。また、ウォーキング中に警告を表示するためには、負担度の変化を推定する必要がある。歩行中の負担度は、歩行速度や勾配、運動強度とその継続時間によって変化すると考えられ、例えば、負担度が高くなるような急な上り坂を歩いたとしても、その後に平坦な道をしばらく歩けば、負担度は徐々に低くなっていく。このような連続的な負担度の変化まで推定するためには、瞬間的な歩行速度や勾配の変化に加えて、運動の継続時間も考慮した負担度の推定を行う必要がある。

以上のことから、提案システムを実現するには、下記の要件を満たす必要がある。

- (1) 普及デバイスによる負担度の測定
- (2) ウォーキング中の負担度変化の推定
- (3) 様々なルートにおける歩行データの効率良い収集
- (4) 年齢、性別、身体能力などの個人差の考慮

これらの要件を満たすための基本方針について述べる。要件 (1) については、近年普及しているスマートフォンに

着目し、搭載されたセンサのみを用いた負担度推定を行うことで、特殊デバイスの装着に伴う手間やコストなどの負担を軽減する。要件 (2) については、歩行データ (加速度、歩行速度、勾配、位置などの時系列データ、詳細は後述) から負担度と関連性の強い心拍数を予測する負担度モデルを作成する。これは後述するように、ニューラルネットワークなどの機械学習を使用し、歩行速度、勾配などのデータを入力とするモデルを作成する。更に、歩行速度や勾配の情報を基に算出する酸素摂取量の増減値を入力に加え、運動強度の変化と運動の継続時間を考慮する。要件 (3) については、ユーザ参加型センシング (Participatory Sensing) [10] によるデータ収集を行う。ここでは、スマートフォン用のデータ収集アプリをユーザに配布し、広範囲における歩行データを効率良く収集する。収集データをサーバ上のデータベースで共有することで、ユーザが初めて歩行するルートに対しても負担度の推定が可能となる。またデータが増えるにつれ、システムが提示する負担度の信頼性が向上すると考えられる。要件 (4) については、「20 代男性、運動習慣有り」、「30 代女性、運動習慣無し」というように、年齢や性別などの属性によりカテゴリを作成する。同一カテゴリに属するユーザは同程度の負担を感じるという前提の下、カテゴリ毎に歩行データの収集や負担度モデルの作成を行うことで、負担度に関する個人差を考慮する。

3.3 提案システムの設計

以上の節で述べた目的および要件をふまえ、提案システムの概要について述べる。提案システムは、ウォーキングを通して運動を行いたいユーザを対象とし、3 軸加速度センサおよび GPS センサを搭載したスマートフォン用アプリケーションとしての利用を想定する。

図 1 に提案システムの概要図を示す。本システムは、クラウド上に置かれている共有データベースおよびサーバ、そしてユーザが装着するスマートフォンから構成される。

共有データベースには、加速度センサおよび GPS センサにより測定するユーザの歩行データが蓄積される。ここでの歩行データとは、加速度の振幅および周波数、歩行速度、勾配、位置情報を指す。加えて、共有データベースには、推定した心拍数および負担度も蓄積する。年齢や性別などの属性により分類されるカテゴリごとにデータを蓄積



図 2 歩行ルート推薦画面の例

することで、様々なユーザに対する歩行データを共有する。

本システムの歩行ナビゲーションは、スマートフォン内のアプリケーションを介して行う。まずユーザは、希望する運動時間および消費カロリー、プロフィールの入力、加えて、マップ上で出発地点および到着地点の選択を行う(図 1 (1))。そして入力されたプロフィールからユーザが属するカテゴリを決定し、共有データベースに蓄積されている該当カテゴリのデータを基に、推薦歩行ルートの決定、更に、図 2 に示すように、スマートフォンの画面にルートと負担度の表示を行う(図 1 (2) ~ (5))。推薦歩行ルートの決定方法については、3.4 節で述べる。

ユーザのウォーキング開始後、スマートフォンにより取得された歩行データは、定期的にクラウド上にアップロードされる(図 1 (2))。サーバ上では、負担度モデルにこのデータを与えることで心拍数および負担度の推定を行い、ユーザに無理な負担がないかどうかを確認する(図 1 (3))。ユーザの歩行速度が適切でない場合には、「もう少しゆっくり歩いてください」や「やや早めに歩いてください」などの歩行速度に関するアドバイスを提示する(図 1 (3) ~ (5))。ウォーキング中または終了時に、ユーザの主観的な負担度もしくは心拍数データ(心拍計を装着していた場合のみ)をアップロードしても良い。このデータは、ユーザの歩行データと共に共有データベースに蓄積される。ユーザビリティを保つという観点から、主観的負担度の評価もしくは心拍数データの提供は必須ではなく、各ユーザの意志に委ねる。

3.4 推薦歩行ルートの決定方法

以下に示す推薦歩行ルート決定アルゴリズムを用いて、ユーザが希望する運動時間および消費カロリーを満たし、かつ、ユーザにとって負担が最小の歩行ルートを推薦する。

手順 1: カテゴリ決定 ユーザが入力したプロフィール情報により、ユーザのカテゴリを決定する。

手順 2: 候補ルートの選択 ユーザがマップ上で選択した出発地点および到着地点の情報を基に、一定距離(2m/秒×運動時間など)以内の候補となる歩行ルートを全て見つけ出し、これらを候補ルート群とする。

手順 3: 歩行速度の算出 候補ルート群に属する各ル

トに対し、歩行速度の算出を行う。ここでは、各ルートの距離をユーザの希望する運動時間で除算することで歩行速度を求める。ただしユーザが一定速度で歩行するとは限らないため、ルートの勾配を考慮し、勾配に応じて時間を傾斜配分する。勾配は与えられているものとする。

手順 4: 消費カロリーの計算 手順 3 で計算した歩行速度および勾配を基に、ACSM (American College of Sports Medicine) により定義された下記の算出式 [11] を用いて、各ルートに対する消費カロリーを求める。

$$C = VO_2 * 5.01$$

$$VO_2 = R + H + V$$

$$R = 3.5$$

$$H = 0.1 * speed$$

$$V = 1.8 * speed * grade$$

ここで、 C [kcal] は消費カロリーを表し、これは酸素摂取量 VO_2 [ml/Kg/min] から算出できる。 VO_2 は、安静時の酸素摂取量 R 、歩行速度に基づく水平方向の酸素摂取量 H 、勾配の増加に伴い必要となる垂直方向の酸素摂取量 V から求められる。また、 $speed$ [m/min]、 $grade$ [%] はそれぞれ、手順 3 で求めた歩行速度、勾配を表す。

手順 5: 心拍数および負担度の推定 各ルートに対し、4 章で述べる手法を使用して、歩行時の心拍数および負担度を推定する。ここでは、共有データベース内の該当カテゴリにおいて、同一ルートの歩行データを基に心拍数の推定を行い、負担度およびその時間変化について推定する。

手順 6: 推薦歩行ルートの決定 候補ルート群に属するルートの中から、下記条件を満たすものを推薦歩行ルートとする。

- (1) 手順 4 で求めた消費カロリーが、ユーザの希望する消費カロリーを超える
- (2) 手順 5 で推定した負担度について、表 2 の 4 (休憩したい程、負担が高い) および 5 (負担が高く、継続が困難) の状態になる合計時間が最小である

4. スマートフォンによる身体的負担度の推定

提案手法では、スマートフォンから取得する歩行データから心拍数を予測する負担度モデルを作成する。ここでは、2.1 節で述べたボルグ・スケールに着目し、心拍数から負担度を定量的に評価できるという仮定の下、歩行データを基に心拍数予測を行う。そして、表 1 に示す小野寺ら [12] が考案した日本語版ボルグ・スケールを基に、表 2 のように負担度レベルを設定し、予測した心拍数から負担度を推定する。

加速度と心拍数の間には、非線形的な関係が見られる [3]。したがって本研究では、入力である歩行データと心拍数の非線形な対応関係を再現するニューラルネットワークを用い、心拍数の予測を行う。負担度モデルの作成には、(a)

表 1 ボルグ・スケール

RPE	主観的運動強度	RPE	主観的運動強度
20		12	
19	非常にきつい	11	楽である
18		10	
17	かなりきつい	9	かなり楽である
16		8	
15	きつい	7	非常に楽である
14		6	
13	ややきつい		

表 2 心拍数と負担度評価の関係

レベル	主観的評価	心拍数 (bpm)
1	負担を感じない	60~105
2	やや負担を感じる	106~125
3	負担は感じるが、運動の継続は可能	126~145
4	休憩したい程、負担が高い	146~180
5	負担が高く、継続が困難	181~200

スマートフォンによる歩行データの取得、ニューラルネットワークに与える入力に関する処理を行うための (b) 特徴量の抽出、(c) 学習データによるモデルの作成、という3つのフェーズに分けられる。以下の節で (a) ~ (c) について述べる。

4.1 (a) スマートフォンによる歩行データの収集

運動強度に関連のあるデータとして、加速度の振幅や周波数、歩行速度、勾配などがある。トレッドミルを用いて歩行中の加速度を測定する予備実験の結果、歩行速度によって加速度の振幅に違いが見られた。また3.4節で示したカロリー消費量の算出式より、運動強度の指標の1つである酸素摂取量が歩行速度および勾配から算出できることが分かる。以上より本研究では、スマートフォンに搭載されている加速度センサおよびGPSセンサにより、加速度および位置情報を収集する。このような時系列のデータがあれば、加速度データから加速度の振幅および周波数を、位置情報より歩行速度および勾配を取得することができ、更には、歩行速度および勾配から酸素摂取量が算出できる。

4.2 (b) 特徴量の抽出

収集した加速度データおよび位置情報を基に、加速度の振幅および周波数、歩行速度、勾配を算出する。更に、歩行速度および勾配から算出した酸素摂取増減値を入力として与え、運動強度とその継続時間を考慮した負担度の推定を行う。

加速度の振幅および周波数の抽出 ここでは、3軸加速度センサにより得られた各軸のデータおよび3軸合成のデータを使用する。前処理として周波数0Hzの直流成分を

除去した各データを、ハーフ・オーバーラップ方式で一定時間のウィンドウに区切り、ウィンドウごとに平均振幅およびパワースペクトルにおいてエネルギーが最大となる周波数（以下、周波数ピーク）を抽出する。ウィンドウサイズは1024点（20.48秒）とする。

歩行速度および勾配の算出 次に示す式により、歩行速度および勾配を算出する。

$$Speed = Dist/Time/(1000 * 3600)$$

$$Degree = 100 * AltDiff/Dist$$

ここで、 $Speed$ [km/h] は歩行速度、 $Degree$ [%] は勾配を表す。また、 $Dist$ [m] および $AltDiff$ [m] はそれぞれ、GPSセンサにより3秒おきに取得する2点間の移動距離および標高差を表し、これらはGoogle Maps API version3により取得する。

酸素摂取増減値の算出 酸素摂取量は心拍数と高い相関関係があり、これらは各運動強度に対応した値まで瞬間的に増大するのではなく、運動開始後2~3分で定常値へと近づく。また歩行状態から安静状態になる場合も同様に、瞬間的に変化するのではなく徐々に減少する [13]。

一定強度の運動を行ったとき、酸素摂取量の増加量 U [ml/kg/min] および減少量 D [ml/kg/min] は、増加時の定常値 K_u [ml/kg/min]、減少時の定常値 K_d [ml/kg/min]、定常値に至るまでの変化速度を表すパラメータ T 、時刻 t [s] を用いて次式のように表される [13]。

$$U = K_u e^{-\frac{t}{T}} \quad (1)$$

$$D = K_d (1 - e^{-\frac{t}{T}}) \quad (2)$$

本研究では、3.4節の手順4で示したACSMの消費カロリー算出式を用いて、一定時間 P [s] における平均歩行速度および平均勾配から酸素摂取量 V_{now} [ml/kg/min] を算出する。 V_{now} が P 秒前の値 V_{pre} [ml/kg/min] と比較して増加した場合には、 $K_u = V_{now}$ として上記の式 (1) を用いて増加量を計算する。逆に V_{pre} と比較して減少した場合には、 $K_d = V_{now}$ として上記の式 (2) を用いて減少量を計算する。 $V_{now} = V_{pre}$ の場合には運動強度に変化がないものと考え、 P 秒前の状態が増加傾向であれば $K_u = V_{now}$ として上記の式 (1) を、減少傾向であれば $K_d = V_{now}$ として上記の式 (2) を用いて変化量を計算する。パラメータ値は、経験的に、 $T = 53$ 、 $P = 60$ とする。

4.3 (c) 学習データによるモデルの作成

負担度モデルの作成には、データマイニングツール WEKA3 [14] を使用する。このツールでは、入力層、出力層、中間層を持つ階層型ニューラルネットワークが利用できる。ここでの学習は教師あり学習と呼ばれ、学習に必要な教師データ（以下、学習データ）により、予め、入出力の関係を学習させることで負担度モデルを作成する。作成

したモデルに対し、ある時刻 t_0 から現在時刻 t_n における加速度や歩行速度などの時系列データ（以下、テストデータ）を与え、これより算出された時刻 t_0 から時刻 t_n までの心拍数が出力値（予測値）となる。実際に使用したデータについては、次章で述べる。

5. 負担度モデルによる推定精度の評価

5.1 目的と方法

評価の目的は、4章で述べた負担度モデルを用いて予測した心拍数および負担度が、提案システムを利用する場合に十分正確であるか調査することである。本稿では評価実験として、トレッドミルを用いて測定したデータ、一般道で測定したデータから負担度モデルをそれぞれ作成し、推定精度を評価をする。前者の実験では、ニューラルネットワークに与える有用な入力についての検討（評価1）を行い、後者の実験では、評価1の結果をふまえて、心拍数および負担度の推定精度の評価（評価2）を行う。

評価1については、各軸の加速度データおよび3軸合成の加速度データから抽出する振幅 (AX, AY, AZ, A) および周波数ピーク (FX, FY, FZ, F), 歩行速度 (S), 勾配 (G), 酸素摂取増減値 (VO) の計11個の特徴量から、有用な入力の組み合わせについて検討する。評価2については、表2において心拍数が少なくとも20bpm増加すると負担度レベルが1レベル高くなることから、平均絶対誤差10bpmを目指し、負担度の誤検出を1レベル以下に抑えることを目標とする。また、提案システムの実用の観点から、負担度が低い場合に高いと判定される誤検出 (false positive) よりも負担度が高い場合に低いと判定される誤検出 (false negative) を抑える必要があると考えられる。これより本稿では、false positive の出現率 (FP (%)) および false negative の出現率 (FN (%)) を算出する。

5.2 実験環境

実験では、腕時計型のワイヤレス心拍計 (SUUNTO, t6d) を腕に装着し、腰 (正面, 中央) にスマートフォン (Sony Ericsson, Xperia active) を装着した。スマートフォンは、搭載されている加速度センサが図3に示す向きになるよう固定した。またサンプリング間隔は、加速度を20ミリ秒、




図3 加速度センサの向き

表3 学習データ

ステージ	1	2	3	4
時間 (分)	3	3	3	3
歩行速度 (m/h)	3.2	3.2	4.8	4.8
勾配 (%)	0	7	7	10
METs	2.5	4.4	6.1	7.4

表4 テストデータ1

ステージ	1	2	3	4
時間 (分)	3	3	3	3
歩行速度 (m/h)	4.0	4.0	4.0	3.2
勾配 (%)	0	5	10	0
METs	2.9	4.6	6.3	2.5

表5 テストデータ2

ステージ	1	2	3	4
時間 (分)	3	3	3	3
歩行速度 (m/h)	4.8	3.2	4.8	4.0
勾配 (%)	0	0	10	0
METs	3.2	2.5	7.4	2.9

表6 実験結果 (トレッドミル)

入力	相関係数		平均絶対誤差 (bpm)		平均二乗誤差 (bpm)	
	case1	case2	case1	case2	case1	case2
FY, AX, S, VO	0.88	0.75	3.86	8.82	5.02	13.00
F, VO	0.93	0.93	6.05	5.63	7.11	7.07
VO	0.96	0.95	7.24	4.96	7.93	6.16
FX, FY, VO	0.92	0.94	7.48	6.18	8.39	7.86

心拍数を2秒、GPSによる位置情報を3秒とし、被験者を1人とした。

5.3 トレッドミルを用いた実験

予備実験として、歩行速度および勾配を任意に設定可能であるトレッドミルを用いた実験を行った。

5.3.1 モデル作成に使用するデータ

この実験では、表3に示すようなステージ1からステージ4までの異なる歩行速度、勾配での歩行を3分間ずつ順次行いながら、心拍数および加速度の測定を行う。

負担度モデルの作成では、学習データに表3に示す条件下で測定したデータ、テストデータに表4および表5に示す条件下で測定したデータを使用した。

5.3.2 実験結果および評価

表6に実験結果を示す。ここで、case1は学習データとテストデータ1により得られた結果、case2は学習データとテストデータ2により得られた結果である。表6ではcase1およびcase2に関して、実測値と予測値の相関係数、平均絶対誤差、平均二乗誤差をそれぞれ示す。

この結果より、相関係数が比較的高いことから、入力項

目数は4以下程度で十分であると考えられる。また、酸素摂取増減値（以下、VO 値）を入力に加えることで平均絶対誤差 10bpm 以下の結果が得られている。これ以外にも、入力には加速度の振幅や周波数が有用であると考えられる。また、入力の組み合わせによってはテストデータにより誤差が大きく変化するものがあるが、特に、周波数 (F) および酸素摂取増減値 (VO) を入力とするものが最も誤差の変化が少なく、安定していると言える。

5.4 一般道での実験

5.3.2 節で述べたように、トレッドミルによる実験では、VO 値の有効性が示された。本節ではこの結果をふまえ、一般道を歩行した場合のデータから負担度モデルを作成する。そして、VO 値の有効性を検討するとともに、推定精度について評価を行う。

5.4.1 モデル作成に使用するデータ

一般道として、(A) ~ (C) の3つの歩行ルート歩いた。ルート (A) は高低差の少ない平坦道、ルート (B) およびルート (C) は平坦道、上り坂、下り坂を含む道である。また歩行時間は、それぞれ、6分、20分、40分である。この実験では、学習データとしてルート (A) およびルート (B) を歩いた場合のデータを、テストデータとしてルート (C) を歩いた場合のデータを使用した。

5.4.2 実験結果および評価

5.3.2 節で比較的安定した結果が得られた、周波数 (F) および酸素摂取増減値 (VO) を入力とした場合の結果を図 4 に示す。ここでは青線が心拍計により測定した心拍数の実測値、赤線が負担度モデルにより得られた予測値である。




図 4 入力に周波数 (F), 酸素摂取増減値 (VO) を与えた場合の結果




図 5 入力に周波数 (F, FX), 振幅 (A, AY) を与えた場合の結果

る。この場合、相関係数は 0.31, 平均絶対誤差 15.64bpm, 平均二乗誤差 17.81bpm という結果が得られた (結果 1)。前節で示した結果と比較すると、相関係数が低く、誤差も大きい。

一方、図 5 に示すように、入力として周波数ピーク (F, FX) および振幅 (A, AY) を与えた場合には、より少ない誤差で推定が可能となった。この場合は、相関係数は 0.47, 平均絶対誤差 9.55bpm, 平均二乗誤差 11.62bpm という結果が得られた (結果 2)。

ここで、上記の結果の推定正答率についての評価を行うために、表 2 のように設定した負担度のランクを用いて、負担度レベルを正しく推定した割合 (NE), 実際よりも負担度レベルを高く推定した割合 (FP), 低く推定した割合 (FN) をそれぞれ計算した。結果 1 および結果 2 における分類結果を表 7 および表 8 に、推定正答率 (NE, FP, FN) を表 9 に示す。分類表は、行方向を実測値の負担度レベル、列方向を予測値の負担度レベルとする。そして表の各欄の値は、対応するレベル (実測レベル, 予測レベル) に分類された数の全体に対する割合を表わし、表の全ての欄の値を合計すると 100% となる。例えば表 7 においては、実際の負担度レベルが 1 のデータを負担度レベル 2 に誤って分類した割合は 74.89% であることが分かる。ただし、結果 1 および結果 2 いずれの場合においても、テストデータのサンプル数は 231 個 (10.24 秒おきのサンプル) であり、負担度レベルが 4 および 5 に該当するデータは存在しなかつ

表 7 結果 1 における負担度レベル分類表

		予測レベル				
		1	2	3	4	5
実測レベル	1	0.00	74.89	0.87	0.00	0.00
	2	0.00	19.91	4.33	0.00	0.00
	3	0.00	0.00	0.00	0.00	0.00
	4	0.00	0.00	0.00	0.00	0.00
	5	0.00	0.00	0.00	0.00	0.00

表 8 結果 2 における負担度レベル分類表

		予測レベル				
		1	2	3	4	5
実測レベル	1	44.59	30.30	0.87	0.00	0.00
	2	8.23	12.99	3.03	0.00	0.00
	3	0.00	0.00	0.00	0.00	0.00
	4	0.00	0.00	0.00	0.00	0.00
	5	0.00	0.00	0.00	0.00	0.00

表 9 結果 1 および結果 2 における推定正答率

結果	NE (%)	FP (%)	FN (%)
結果 1	19.91	80.09	0
結果 2	57.58	34.20	8.22

た。また推定正答率については、これらの分類表を基に、NE は対角成分の和、FP は上三角成分の和、FN は下三角成分の和として計算する。

表 7 および表 8 より、今回行った一般道での実験では、負担度レベルの誤推定を 1 レベル以内に抑えることができたことが分かる。しかし、トレッドミルによる実験で有効性が見られた VO 値の入力は一般道の場合には有効であるとは言えず、表 9 の結果 1 では FN が 0% であったにも関わらず、FP (80.09%) が NE (19.91%) をはるかに上回る結果となった。また表 7 に示すように、負担度レベル 1 に関する分類結果は 0% と誤差が大きいことが分かる。それに対して結果 2 では、加速度の振幅が推定に効果的に働き、平均絶対誤差は 10bpm 以下となり、NE も 60% 近い結果を得ることができた。しかし、FN の発生が見られ、FP および FN の合計が 42.42% であることから、提案モデルの推定精度をより向上させる必要があると考えられる。

5.5 考察

5.3.2 節および 5.4.2 節で示した結果より、入力としては、トレッドミルによる実験では VO 値が有用であったのに対し、一般道での実験では加速度の振幅が有用であった。これは、トレッドミルの場合は歩行速度および勾配が一定であったために VO 値の算出が比較的容易であったのに対し、一般道の場合は、歩行速度および勾配を GPS による位置情報から算出するため誤差が多く、VO 値にも影響していると考えられる。

今後は、加速度データを基に歩行速度を算出し、再度、VO 値の入力の有効性を検討する必要がある。また、今回の実験では、負担度レベルが 2 以下となる負担の少ないデータを使用した。更に心拍数が増加するような負担度の高い一般道を選択した上で、FP および FN の出現率について実験する必要がある。

6. まとめ

本稿では、スマートフォン搭載センサのみを用いた負担度推定手法と、その手法に基づいた、個人の身体能力に応じた歩行ルートを推薦する提案システムについて述べた。負担度モデルの評価実験では、トレッドミルを用いた場合に VO 値の入力の有効性が示されたが、一般道で収集した場合は更なる改良が必要であることが分かった。また一般道での実験では、10bpm 以下の平均絶対誤差で推定が可能となったものの、負担度レベルの誤推定が多く、誤差の減少および推定精度の向上が必要である。今後は、歩行速度の算出方法や VO 値の算出方法について改善する他に、学習に使用するデータについても、データ量を増やすことや複数の被験者から収集したデータの使用が必要であると考えられる。

参考文献

- [1] Lara, Ö. D., Pérez, A. J., Labrador, M. A. and Posada, J. D.: Centinela: A human activity recognition system based on acceleration and vital sign data, *Journal on Pervasive and Mobile Computing* (2011).
- [2] Tapia, E. M., Intille, S. S., Haskell, H. W., Larson, K., Wright, J., King, A. and Friedman, R.: Real-Time Recognition of Physical Activities and Their Intensities Using Wireless Accelerometers and a Heart Rate Monitor, *Proc. of 11th International Symposium on Wearable Computers (ISWC2007)*, pp. 37-40 (2007).
- [3] Xiao, F., Chen, Y., Yuchi, M., Ding, M. and Jo, J.: Heart Rate Prediction Model Based on Physical Activities Using Evolutionary Neural Network, *Fourth International Conference on Genetic and Evolutionary Computing*, pp. 198-201 (2010).
- [4] Borg, G.: Psychophysical scaling with applications in physical work and the perception of exertion, *Scandinavian Journal of Work Environment Health*, Vol. 16 (SUPPL 1), pp. 55-58 (1990).
- [5] Borg, G.: Psychophysical scaling with applications in physical work and the perception of exertion, *Med. Sci. Sports Exerc.*, Vol. 5, No. 2, pp. 90-93 (1973).
- [6] SUUNTO, : スポーツコンピューター TRAINING t6d, 入手先 <<http://www.suunto-japan.jp/products/list/sportscomputer/training/t6d>>: (参照 2011-08-22) .
- [7] POLAR, : ハートレイトモニター RS100, 入手先 <http://www.polar.co.jp/ja/products/get_active/running-multisport/RS100>: (参照 2011-08-22) .
- [8] SONY, : ポータブルナビゲーション NAV-U, 入手先 <<http://www.sony.jp/nav-u/contents/>>: (参照 2011-11-29) .
- [9] NAVITIME, : 自転車ルート検索, 入手先 <<http://www.navitime.co.jp/bicycle/>>: (参照 2011-06-12) .
- [10] Goldman, J., Shilton, K., Burke, J., Estrin, D., Hansen, M., Ramanathan, N., Reddy, S., Samanta, V. and Srivastava, M.: Participatory Sensing: A citizen-powered approach to illuminating the patterns that shape our world, *Foresight & Governance Project, White Paper* (2009).
- [11] Sports Medicine, of A. C.: *ACSM's Guidelines for Exercise Testing and Prescription (7th edition)*, Lippincott Williams & Wilkins, Philadelphia (2005).
- [12] 小野寺孝一, 宮下充正: 全身持久性運動における主観的強度と客観的強度の対応性: Rating of perceived exertion の観点から, *体育学研究*, Vol. 21, No. 4, pp. 191-203 (1976).
- [13] 佐川貢一, 石原正, 猪岡光, 猪岡英二: 歩行形態の違いを考慮した消費カロリーの無拘束推定, *計測自動制御学会*, No. 183-7 (1999).
- [14] WEKA3, : Data Mining with Open Source Machine Learning Software in Java, 入手先 <<http://www.cs.waikato.ac.nz/ml/weka>>: (Accessed 2011-11-29) .